

YAPAY SİNİR AĞLARI İLE FONKSİYON BELİRLEME

Nevra AKBİLEK, Semra BORAN

Özet - İstatistik yöntemler, endüstriyel uygulamalarda oldukça yoğun bir şekilde kullanılırlar. Veriler arasındaki ilişki bilindiğinde, bir değişkenin değerine bakarak diğerini tahmin edebileceğimiz gibi etki eden faktörleri kontrol altına alabilirsek bizi ilgilendiren değişkenlerin değerini optimum düzeye getirebiliriz. Bu bakımdan gözlem değerlerinin ifade ettikleri ilişki ya da fonksiyon tipinin belirlenmesi daima bir ihtiyaçtır. Deney ve gözlemler elde edilen verilerin bütünü ele alındığında uygunluk gösterdiği fonksiyon bulunabilmektedir. Bu aşamada istatistiksel değerlendirmelere ihtiyaç duyulduğundan Regrasyon Korelasyon Analizinin bilinmesi gerekmektedir. YSA herhangi bir prosesin girdi ve çıktıları arasındaki ilişkiyi (doğrusal olsun veya olmasın) elde bulunan mevcut örneklerden genellemeler yaparak ortaya koymakta ve bu genelleme ile yeni oluşan veya ortaya çıkan daha önce hiç görülmemiş proses girdilerine karşılık gelecek çıktıyı önceki örneklerden çağırışım yaparak belirlemektedirler. Bu çalışmada mevcut fonksiyon belirleme metotlarının hız, doğruluk ve yüksek performans açısından sundukları dezavantajların giderilmesi amaçlanmıştır.

Yapay sinir ağları modellerinden özellikle optimizasyon ve model tanıma popülarite kazanmış olan Çok Katmanlı Algılayıcı (ÇKA) modeli kullanılarak bir veri setinin fonksiyon türünü belirleyebilen bir sistem geliştirilmiştir. Kullanılan fonksiyonlar $Y=a+bx$, $Y=a+bx^2$, $Y=a+b/x$, $Y=a+b/x^2$ zaman serileri modelleridir. Çalışma sonucunda SPSS Programı ve eğitilmiş ağa görmediği örneklerden her bir fonksiyon türünü ifade eden Y değerleri verilmiştir. YSA'nın fonksiyon türünü tahmin edebildiği ispatlanmıştır.

Anahtar Kelimeler - Çok Katmanlı Algılayıcı, Regrasyon Korelasyon Analizi, Yapay Sinir Ağı.

Abstract - Now it is possible to mention about many successful applications in real life. In this study a system that can define function type of a data set is

N.AKBİLEK, S. BORAN, SAÜ Müh. Fak., Endüstri Müh. Bölümü.

developed by using Multilayer Sensor Model that is popular in especially optimization and model recognition of neural networks models. The success of neural networks in this study is derived from processing complex and uncertain information, learning ability of complex and linear or nonlinear relations between process parameters.

Employed functions $Y=a+bx$, $Y=a+bx^2$, $Y=a+b/x$, $Y=a+b/x^2$ functions are time series models. The model set was tested after training. Neural networks bring up the relation between inputs and outputs of any process (linear or nonlinear) by generalizing present examples and define the output for newly formed or appeared never seen before process inputs by connotation with this generalization.

Keywords - Regression and Correlation Analysis, Neural Networks, Multilayer Perceptron

I. GİRİŞ

Yapay sinir ağları ve regresyon üzerine yapılan teorik ve pratik çalışmalar her geçen gün biraz daha artmaktadır. Artık gerçek hayatta bir çok başarılı uygulamalardan bahsetmek mümkündür. Günlük hayatta karşılaştığımız birçok probleme baktığımızda bir veya birçok faktörün etkili olduğunu görebiliriz. Bu faktörlerin her biri bir değişken olarak gözönüne alınırsa bazıları arasında matematik bir fonksiyonla ifade edilebilen kesin ilişkilerin mevcut olduğu anlaşılır. Bu ilişkiler genellikle çok sağlam bir teoriye dayanan ve günümüzde geçerliliği kanıtlanmış ilişkilerdir. Bunlara Belirleyici (Deterministik) ilişkiler denilir.

Birçok durumda değişkenler arasındaki ilişki teorik olarak bilinmesine karşın bu ilişkinin matematik ifadesindeki bazı parametrelerin deneysel olarak saptanması gerekmektedir. Bu parametrelerin saptanabilmesi için deneyler yapılırken ölçüm aletlerinin hassasiyetlerinin tam olmayışı gibi çeşitli nedenlerle hataların yapılması söz konusudur. Böylelikle gerçek ilişki ancak belli bir hata payı içinde açıklanabilmektedir. Bunlar ise yarı belirleyici ilişkiler sınıfına girmektedir.

Yukarıda anlatılan ilişkilerin aksine günlük hayatta sık sık karşılaştığımız olaylar arasındaki ilişkileri açıklayan bir teori yoktur. Buna karşın yapılan gözlemler eğer bir mili metrik kağıt üzerine işaretlenirse bu değişkenler arasında bir ilişki olduğu görülebilir. Daha sonra ilişkinin bu gözlenen şekline uyan bir matematik model geliştirilerek çeşitli amaçlar için kullanılabilir ve deneysel ilişkiler adı altında incelenir. Regresyon analizi yarı belirleyici ve deneysel ilişkileri kapsar ve inceler.

Bu çalışmada mevcut fonksiyon belirleme metodlarının hız, doğruluk ve yüksek performans açısından sundukları dezavantajların giderilmesi amaçlanmıştır. Seçilmiş zaman serileri modelleri dikkate alınarak gözlem değerlerinin hangi fonksiyona daha iyi uyum gösterdiği araştırılmıştır. Verilerin gösterdiği fonksiyon ya da ilişki ile ilgili mevcut teorik fonksiyonları tek tek mukayese etmek zaman alıcı ve karmaşık bir prosestir. Bu dezavantajları gidermek için klasik programlamaya alternatif olarak YSA ile yeni bir yaklaşım denenmiştir.

Çalışmalar, fonksiyon türünü belirleme metodu olarak yapay sinir ağı modellerinden Çok Katmanlı Algılayıcı (ÇKA) modelinin kullanılıp kullanılmayacağı üzerinde yoğunlaşmıştır. Bu modelin detaylı özellikleri ve kullandığı öğrenme kuralı Rumelhart ve Arkadaşları (1986) tarafından oldukça güzel bir şekilde anlatılmıştır. ÇKA sinir ağının model tanıma özelliğinden faydalanılarak daha önce özellikle kontrol kartlarının tanınması ve böylece prosesin otomatik denetiminin sağlanması için bir takım çalışmalar yapılmıştır (Hwang ve Hubele 1991, Pham ve Öztemel 1993). Özellikle Pham ve Öztemel proses eğilimini hem ÇKA hem de LVQ yapay sinir ağları modelleri ağları ile belirledikten sonra ikisini bileşiminden oluşan bir kompozit model oluşturmaları dikkate değerdir.

YSA ve istatistik yöntemler kullanılarak yapılan çalışmalara bakıldığında genellikle tahmin amacıyla kullanıldığı görülmektedir [2-9].

Çalışma beş bölümden oluşmaktadır. İkinci bölümde regresyon korelasyon analizi tanıtılmaktadır. Üçüncü bölümde kısaca yapay sinir ağları ve özel olarak ÇKA modeli, dördüncü bölümde ise önerilen metod detaylı olarak anlatılmaktadır. Son bölümde ise sonuç ve gelecekle ilgili yapılabilecek çalışmalar üzerinde durulmaktadır.

II. REGRESYON ANALİZİ

Değişkenler arasında ilişkiler çok değişik şekillerde olabilmektedir. Regresyon analizinde genellikle bağımsız değişkenler (x), bağımlı değişkenler ise (y) ile gösterilirler.

Regresyon analizi, herhangi bir bağımlı değişkenin, bir veya birden fazla değişkenle (bağımsız-açıklayıcı değişken) arasındaki ilişkinin matematik bir fonksiyon şeklinde yazılmasıdır. Bu fonksiyona regresyon denklemi adı verilmektedir. Regresyon denklemi yardımıyla açıklayıcı değişkenlerin çeşitli değerlerine karşılık bağımlı değişkenin ulaşacağı değer tahmin edilir. Regresyon analizi başlığı altında ikinci önemli analiz olan "korelasyon analizi"nin (Correlation Analysis) önemi bu aşamada ortaya çıkmaktadır. Korelasyon gücünü derece olarak gösteren ve yüzde olarak ifade eden bir katsayıdır.

Regresyon analizi, çeşitli kriterlere göre sınıflandırılır. Bağımsız değişken sayısına göre;

1. Basit regresyon analizi (Tek bağımsız değişken)
 2. Çoklu regresyon analizi (Birden çok bağımsız değişken)
- fonksiyon tipine göre;
1. Doğrusal regresyon analizi,
 2. Doğrusal olmayan regresyon analizi (eğrisel)
- verilerin kaynağına göre;
1. Ana kütle verileriyle regresyon analizi,
 2. Örnek verileriyle regresyon analizi,
 3. Zaman serilerinde regresyon analizi (eşleştirilmiş zaman serileri).

Ana kütle için basit doğrusal regresyon denklemi:


$$Y=A+BX+\Sigma \quad (1)$$

Örnek için ise,

$$Y=a+bx+e \text{ şeklinde yazılır.}$$

Çalışmada örnek verileriyle doğrusal olan ve olmayan basit regresyon analizi kullanılmıştır.

A doğrusal fonksiyonun sabitidir. X=0 olduğunda, regresyon doğrusunun dikey eksen Y'yi kestiği noktayı göstermektedir. B ise doğrusal fonksiyonun eğimidir. Regresyon analizinde bağımsız değişken X'de ki bir birimlik değişiminin bağımlı değişken Y'de (Y cinsinden) ne kadarlık bir değişime yarattığını gösteren regresyon katsayısıdır. a ve b ise anakütle regresyon katsayılarının (A ve B) tahminleyenidir. Fonksiyon tipinin belirlenmesi için regresyon analizine serpilme diyagramı çizilerek başlanır. Serpilme diyagramında gözlem noktaları dağılımı Şekil 2.1'de görüldüğü gibi doğrusal bir eğilimdedir.




Şekil 2.1 Serpilme Diyagramı

Her iki değişken birlikte artıyor veya azalıyorsa B'nin işareti pozitif(+), biri artarken diğeri azalıyorsa B'nin işareti (-) olacaktır. B'nin 0 olması ise iki değişken arasında ilişki olmadığını göstermektedir. Bu açıklamalardan anlaşılacağına göre regresyon katsayısının alt sınırı (0) vardır, ancak belirli bir üst sınırı yoktur. Basit doğrusal regresyon denkleminde e veya Σ ile gösterilen değer hata (error) terimidir. Buna artık veya kalıntı (residual) adı da verilir. $\Sigma=(Y-Y')$ dir. Y' tahmini (teorik) bağımlı değişken değerini göstermektedir.

II.1. Doğrusal Regresyon Denkleminin Yazılışı:

Çeşitli X değeri karşısındaki Y değerlerinin dağılımını gösteren (Şekil 2.1) serpilme diyagramları incelendiğinde doğrusal bir eğilim gözüküyorsa X'in Y'ye göre matematik fonksiyonunun doğrusal olduğuna karar verilebilir. Ancak gözlem noktaları arasında çok sayıda doğrusal fonksiyon geçirilebilir.



Şekil 2.2 Hataların Dağılımı

Bu fonksiyonlardan en uygunu (tüm doğrusal fonksiyonlar arasında) Y gözlem değerine en yakın tahmini (teorik) Y' değerini (minimum hata) veren

doğrusal fonksiyon olacaktır. Demek ki hatası $e=y-y'=y-a-bx$ =minimum olan fonksiyon seçilmelidir. Hataların dağılımı Şekil 2.2'deki gibidir. Tüm gözlem değerleri için bu durumun geçerli olması gerektiğine göre; $\Sigma(y-a-bx)^2$ =minimum yapılması gerekir. Bu yöntem "En Küçük Kareler Yöntemi" adı verilmektedir. A ve b değerleri aşağıdaki formüllerle hesaplanır.

$$b = \frac{\sum XY - \frac{\sum X \sum Y}{n}}{\sum X^2 - \frac{(\sum X)^2}{n}} \quad (2)$$

$$a = \bar{y} - b\bar{x} \quad (3)$$

III. YAPAY SİNİR AĞLARI

Yapay sinir ağları proses parametreleri arasındaki ilişkileri, bu ilişkileri gösteren örnekleri kullanarak öğrenme esasına dayanan sistemlerdir. Öğrenme özelliği belkide araştırmacıların dikkatini yapay sinir ağları üzerine çeken en önemli öğelerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi elde bulunan mevcut öğelerden genellemeler yaparak ortaya koymak ve bu genelleme ile yeni oluşan veya ortaya çıkan daha önce hiç görülmemiş olayları, önceki girdilerden çağrışım yaparak ilgili olaya çözümler üretebilmek oldukça önemli bir olaydır. Bu özellik yapay sinir ağlarındaki zeki davranışında temelini oluşturur. Bir sinir ağının zeki davranışı, bağlantı hatları üzerindeki ağırlıkların değerleri ile ölçülür. Sinir ağının genelleme kabiliyeti de yine bu değerler ile alakalıdır. Çünkü bu değerler ağın sahip olduğu bilgiyi temsil ederler. Burada önemli olan husus, ağın zeki davranış gösterebilmesi için sahip olduğu bütün ağırlıkların ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru (optimum) değerlere sahip olmasıdır. Bu doğruluk ne kadar artarsa ağın performansı da o kadar artar. Optimum ağırlık değerleri bir öğrenme kuralına göre tespit edilir. Çoğunlukla bağlantılara, başlangıç değerleri olarak rasgele ağırlıklar atanır ve bu ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek daha iyi değerler bulunmaya çalışılır.

Bir yapay sinir ağının bağımsız ve paralel olarak çalışabilen proses elemanlarının (yapay sinir hücreleri) hiyerarşik bir şekilde organizasyondan (seviye ve katmanlardan) ibarettir. Genel olarak 3 tür katman vardır. Girdi katmanı, ara (gizli) katmanlar ve bir de ağın çıktı katmanı. Her katman proses elemanlarından oluşur. Proses elemanları birbirlerine bağlanmıştır. Her

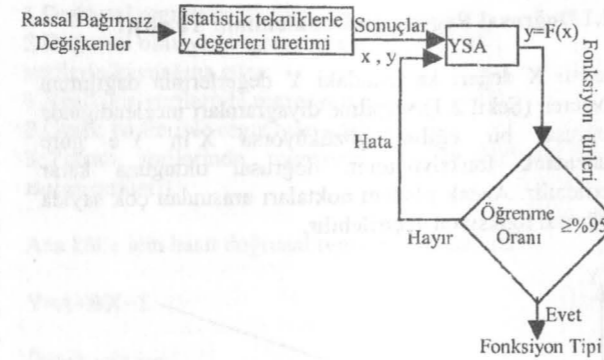
bağlantının bir ağırlığı vardır. Ağın sahip olduğu bilgi düzeyi bu ağırlıklar vasıtasıyla belirlenir. Zaten öğrenmeden kasıt ilgili problemdeki girdi-çıkı ilişkisini en güzel tanımlayacak optimum ağırlıkların bulunmasıdır. Proses elemanı kendisine gelen girdileri toplar (toplama fonksiyonu), işler (aktivasyon fonksiyonu) ve dışarı gönderir. Ağ belirli bir öğrenme kuralına göre bu çıktıları değerlendirir ve ağırlıkları daha iyiye doğru değiştirir. Bu işlemler ilgili problemi gösteren çeşitli ağlardan her biri için defalarca tekrarlanır. Ağın ürettiği çözümdeki hata kabul edilebilir bir düzeye ulaştığında öğrenme durdurulur. Daha sonra ağ öğrendiği bilgiler ile hiç görmediği örneklerle çözüm üretir. Ağın başarısı seçilen problemi temsil etme özelliği ile doğru orantılıdır. Yani eğer örnekler doğru seçilirse öğrenme olayı daha verimli olur. Ağlar oluşturuldukları hiyerarşik yapı, kullandıkları toplama ve aktivasyon fonksiyonları ve öğrenme kuralına göre değişik modeller oluştururlar (Simpson, 1990). Bu çalışmada Çok Katmanlı Algılayıcı (ÇKA) modeli kullanılmış olup bu modelin öğrenme yeteneğinin oluşmasından faydalanılarak fonksiyon tipinin belirlenebileceği gösterilmektedir.

III.1 Fonksiyonların YSA ile Tahmin Edilmesi

Yapay sinir ağları proses parametreleri arasındaki ilişkileri, bu ilişkileri gösteren örnekleri kullanarak öğrenme esasına dayanan sistemlerdir. Öğrenme özelliği belkide araştırmacıların dikkatini yapay sinir ağları üzerine çeken en önemli öğelerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi elde bulunan mevcut öğelerden genellemeler yaparak ortaya koymak ve bu genelleme ile yeni oluşan veya ortaya çıkan daha önce hiç görülmemiş olayları, önceki girdilerden çağrışım yaparak ilgili olaya çözümler üretebilmek oldukça önemli bir olaydır. Bu özellik yapay sinir ağlarındaki zeki davranışında temelini oluşturur. Bir sinir ağının zeki davranışı, bağlantı hatları üzerindeki ağırlıkların değerleri ile ölçülür. Sinir ağının genelleme kabiliyeti de yine bu değerler ile alakalıdır. Çünkü bu değerler ağın sahip olduğu bilgiyi temsil ederler. Burada önemli olan husus, ağın zeki davranış gösterebilmesi için sahip olduğu bütün ağırlıkların ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru (optimum) değerlere sahip olmasıdır. Bu doğruluk ne kadar artarsa ağın performansı da o kadar artar. Optimum ağırlık değerleri bir öğrenme kuralına göre tespit edilir. Çoğunlukla bağlantılara, başlangıç değerleri olarak rasgele ağırlıklar atanır ve bu ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek daha iyi değerler bulunmaya çalışılır.

Bir yapay sinir ağının bağımsız ve paralel olarak çalışabilen proses elemanlarının (yapay sinir hücreleri)

hiyerarşik bir şekilde organizasyondan (seviye ve katmanlardan) ibarettir. Genel olarak 3 tür katman vardır. Dış dünyadan bilgileri alan girdi katmanı, gelen bilgileri işleyen ara katmanlar ve bir de ağın çözümünü dış dünyaya veren çıktı katmanı. Her katman proses elemanlarından oluşur. Proses elemanları birbirlerine bağlanmışlardır. Her bağlantının bir ağırlığı vardır. Ağın sahip olduğu bilgi düzeyi bu ağırlıklar vasıtasıyla belirlenir. Zaten öğrenmeden kasıt ilgili problemdeki girdi-çıkı ilişkisini en güzel tanımlayacak optimum ağırlıkların bulunmasıdır. Proses elemanı kendisine gelen girdileri toplar (toplama fonksiyonu), işler (aktivasyon fonksiyonu) ve dışarı gönderir. Ağ belirli bir öğrenme kuralına göre bu çıktıları değerlendirir ve ağırlıkları daha iyiye doğru değiştirir. Bu işlemler ilgili problemi gösteren çeşitli ağlardan her biri için defalarca tekrarlanır. Ağın ürettiği çözümdeki hata kabul edilebilir bir düzeye ulaştığında öğrenme durdurulur. Daha sonra ağ öğrendiği bilgiler ile hiç görmediği örneklerle çözüm üretir. Ağın başarısı seçilen problemi temsil etme özelliği ile doğru orantılıdır. Yani eğer örnekler doğru seçilirse öğrenme olayı daha verimli olur. Ağlar oluşturuldukları hiyerarşik yapı, kullandıkları toplama ve aktivasyon fonksiyonları ve öğrenme kuralına göre değişik modeller oluştururlar



(Simpson, 1990). Bu çalışmada Çok Katmanlı Algılayıcı (ÇKA) modeli kullanılmış olup bu modelin öğrenme yeteneğinin oluşmasından faydalanılarak fonksiyon tipinin belirlenebileceği gösterilmektedir.

Şekil 3.1 YSA kurulması Akış Diyagramı

IV. ÇOK KATMANLI ALGILAYICI (ÇKA) MODELİ

ÇKA sinir ağı modeli en çok kullanılan sinir ağı modeli olmuştur. Anlaşılması kolay ve matematiksel olarak çalışmasını ispatlanabilir olması bu modelin yaygın kullanımına neden olmaktadır. Bir ÇKA modeli üç katmandan oluşur. Bir giriş, bir veya daha fazla ara ve bir de çıktı katmanı vardır (Şekil 3.1). Bir katmandaki bütün proses elemanları bir üst katmandaki bütün proses elemanlarına bağlıdır. Girdi katmanında herhangi bir bilgi işleme yapılmaz. Buradaki proses elemanı sayısı

tamamen mevcut problemle ilgilidir. Ara katman sayısı ve ara katmanlardaki proses elemanı sayısı ise deneme yanılma yoluyla bulunur. Çıktı katmanındaki eleman sayısı ise yine mevcut probleme dayanılarak belirlenir. ÇKA ağlarında, ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir (öğretmenli öğrenme). Örnekler girdi katmanından alınır, ara katmanlarda işlenir ve çıktı katmanında sonuç üretilir. Sistemin ürettiği çıktı ile üretmesi gereken çıktı arasındaki hata tekrar geriye doğru ağın bağlantı hatlarındaki Delta öğrenme kuralına (Rumelhart ve Arkadaşları, 1986) göre ağırlıklara dağıtılır. Bir sonraki örnek için aynı işlem tekrar yapılır. Bu işlem, öğrenme gerçekleşinceye kadar yani belirli bir öğrenme oranına ulaşıncaya kadar devam eder.

IV.1 Mevcut Fonksiyonların Tespiti ve Rassal Olarak Değerlerin Üretilmesi

0-30 aralığında X Değerleri ve rassal a,b
 $Y = a + bX + \epsilon$, $Y = a + b/X + \epsilon$, $Y = a + bX^2 + \epsilon$
 $Y = a + bX^2 + \epsilon$ formüllerinde yerlerine konularak y değerleri üretilmiştir. $E = (0.5-R) \cdot \sigma_x$ formülünden elde edilmiştir. Bu şekilde her bir fonksiyon türü için hesaplanan 30 adet y değeri bir çıktıyı temsil edecek şekilde veriler hazırlanmıştır.

IV.2 Fonksiyon Tanıma Sisteminin Yapısı

Bu sistem tipik bir ÇKA sinir ağı modelinden oluşturulmuştur. Model, veri seti halinde girilen girdileri işleyip hangi fonksiyona uyduğunu çıktı olarak verir. Topolojik olarak sistem girdi, ara ve çıktı katmanları olmak üzere üç katmandan oluşmuştur. (bkz. Şekil-1). Burada ifade edildiği gibi girdi ve çıktı katmanlarının eleman sayıları problemin doğasına göre ara katman eleman sayısı da deneme yanılma ile belirlenmiştir. Modellerin çıktı elemanları pilot olarak seçilen dört fonksiyonu temsilen Çıktı elemanlarının temsil ettikleri eğriler Tablo-4.1'de de görülebileceği gibi zaman serileri fonksiyonlarıdır. YSA yapısında aktivasyon fonksiyonu olarak Sigmoidal Fonksiyon;

$$f_x = 1 / (1 + e^{-x}) \quad (4)$$

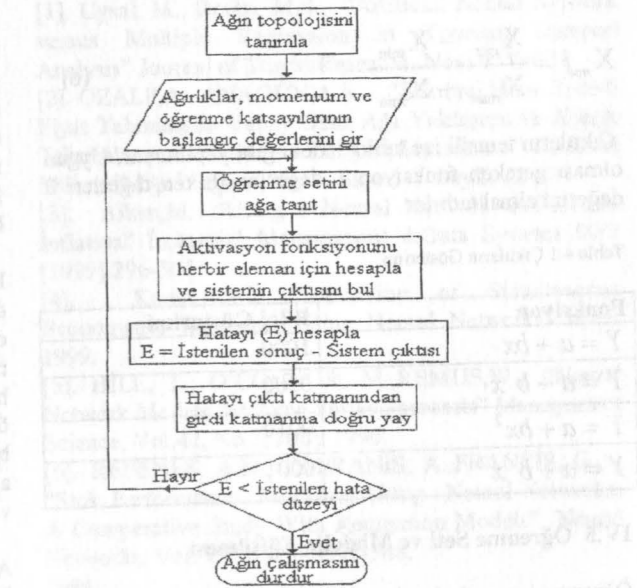
Toplama Fonksiyonu olarak ise Toplam Fonksiyonu;

$$Net_i = \sum W_{ij} I_{ij} \quad (5)$$

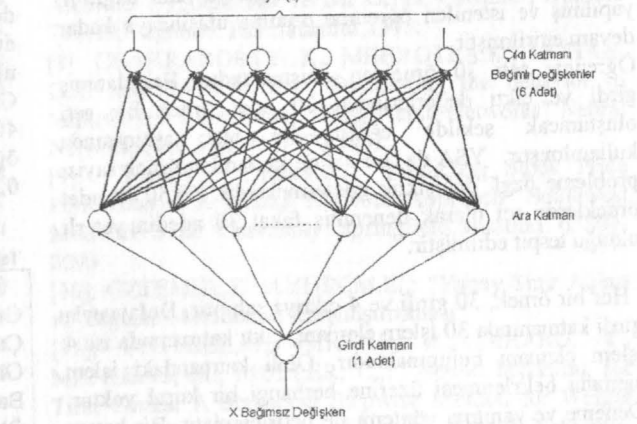
kullanılmıştır

IV.3 Ağ Eğitim Aşamaları ve Akış Diyagramı

Ağın topolojisini tanımlanması, başlangıç ağ parametrelerini belirlenmesi (bağlantı ağırlıkları, öğrenme oranı, momentum katsayısı), öğrenme setinin ağa tanıtılması, aktivasyon kuralını her bir eleman için hesapla ve sistem çıktısının bulunması, istenen sonuçla sistem çıktısı arasındaki hatanın bulunması, aradaki hatanın çıktı katmanından başlayıp geriye doğru bağlantı ağırlıklarına dağıtılması, hata minimum seviyeye ulaşmışsa ağın çalışmasının durdurulması aşamalarından oluşur.



Şekil 4.1 Ağ Eğitimi Akış Diyagramı



Şekil 4.2 ÇKA Modeli

IV.4 NN Modelinin Oluşturulması

Tasarlanan modelin eğitilmesi, sistemin bir yapay sinir ağı olarak geliştirilmesinin doğal bir sonucudur. Bağımsız değişken x değerleri girdi olarak alındı. Kullanılan yazılımın bir gereği olarak bilgiler, [0-1] aralığında ölçeklendirilerek temsil edilmiştir. Yani bağımsız değişkenlerin en büyük ve en küçük değerleri [0-1] aralığında ölçeklendirilmiştir. Ölçeklendirme işleminde bağımsız (açıklayıcı) değişkeni normalize etmek için şu formül kullanılmıştır;

$$X_{nor} = \frac{X_{ger} - X_{min}}{X_{max} - X_{min}} \quad (6)$$

Çıktıların temsili ise tablo-1'deki gibi yapılmıştır. Uygun olması gereken fonksiyon 1 değerini alırken diğerleri 0 değerini almaktadırlar.

Tablo 4.1 Çıktıların Gösterimi

Fonksiyon	Bilgi Gösterimi
$Y = a + bx$	1000
$Y = a + b x$	0100
$Y = a + bx^2$	0010
$Y = a + b x^2$	0001

IV.5 Öğrenme Seti ve Modelin Eğitilmesi

Öğrenme sırasında her iterasyonda örnek setindeki her bir örnek sisteme gösterildikten sonra geriye hata dağıtımı yapılmış ve istenilen öğrenme oranına ulaşıncaya kadar devam ettirilmiştir.

Öğrenme seti 30 örnekten oluşmaktadır. Hazırlanmış girdi ve çıktı değerlerinden 30 adet örnek bir seti oluşturacak şekilde eğitim ile test aşamasında kullanılmıştır. YSA da bir set de kullanılan örnek sayısı probleme özgü değişiklik göstermektedir. 60,50,40 adet örneklerde set olarak denenmiş fakat 30 adedin yeterli olduğu tespit edilmiştir.

Her bir örnek, 30 girdi ve 4 çıktıya sahiptir. Dolayısıyla girdi katmanında 30 işlem elemanı, çıktı katmanında ise 4 işlem elemanı bulunmaktadır. Gizli katmandaki işlem elemanı belirlenmesi üzerine herhangi bir kural yoktur. Deneme ve yanılma yöntemi ile belirlenmiştir. Bir hatayı geriye yayma ağını eğitmede en önemli işlerden birisi, ağı öğrenme ile ilgili bazı parametrelerini belirlemektir. Bu parametreler, öğrenme katsayısı, momentum katsayısı, gizli katman sayısı, ağırlıkların başlangıç

değerlerinin aralığı ve öğrenmeyi durdurma kuralıdır. Bu parametrelerin değerleri Tablo 4.2 de verilmektedir.

Tablo 4.2'deki değerler tamamıyla deneme yanılma yöntemi ile bulunmuştur. Ağı bağlantı ağırlıkları ve bias girdi ağırlıkları, başlangıçta, rasgele belirlenmektedir. İyi başlangıç ağırlık aralığı iyi öğrenmeye neden olmaktadır. İkinci önemli nokta, ağı eğitme, bir başka deyişle, öğrenme ne zaman durdurulmalıdır sorusunun yanıtıdır. Genellikle iterasyon sayısını artırdıkça ağı daha iyi öğrendiği düşünülür. Eğer bu doğru olsaydı, çok büyük bir sonlu iterasyon sayısında öğrenme setini mükemmel bir şekilde öğretmek mümkün olabilecekti. iterasyon sayısını artırmak iyi öğretmeyi gerçekleştirmenin bir tek yöntemi değildir. Bunun yanında doğruluk yüzdesi kuralı da iyi bir yöntemdir. Öğrenmeyi durdurma kuralı, öğrenmenin veya eğitmenin doğruluk derecesiyile ilintilidir. Doğruluk yüzdesi aşağıdaki gibi hesaplanır: $D(\%) = (\text{Doğru olarak sınıflandırılan örnek sayısı} / \text{Toplam örnek sayısı}) * 10$

Doğruluk yüzdesi ,belirli bir noktaya gelindiğinde, diyelim ki % 95, ağı eğitilmesi veya öğrenmesi durdurulur. Ancak bazı genellemeler yapmak mümkündür. Örneğin. Pham ve Öztemel(1992)'in belirttiğine göre 200 epoktan sonra ağı yeterince öğreneceği ifade edilmektedir. Eğer 200 epokta tatminkar bir öğrenme noktasına erişmiyorsa öğrenme setinde, veya ağı parametrelerinde bir problem olduğu kamsına varılması gerektiği ifade edilmektedir.

Ağı eğitimi farklı sayıda iterasyonlar için denenmiş 700.000 ve daha yukarı rakamlarda öğrenme oranının değişmediği görülmüştür. Ağı eğitimi öğrenme ve test dosyasında % 90 öğrenme oranı yakalandıktan sonra durdurulmuştur. En iyi performansa aşağıdaki rakamlarla ulaşılmıştır.

Gizli katman sayısı: 40,50,55
öğrenme ve momentum katsayısı : 0.2-0.8;0.3-0.8;0.3-0.9

Tablo 4.2 Ağı Parametreleri

Girdi Sayısı	30
Çıktı Sayısı	4
Gizli Katman Sayısı	40-70
Başlangıç Ağırlıklarının Aralığı	-0,1 ile 0,1
Ölçekleme Aralığı	0 ile 1
Öğrenme Katsayısı	0,2-0,3-0,4
Momentum Katsayısı	0,9-0,8-0,7
Hata Payı	%35

IV.6 Test Aşaması

IV.6.1 Eğitilmiş YSA ve SPSS Paket Programı Sonuçlarının Karşılaştırılması

Yapılan Çalışma sonucunda SPSS Programı ve eğitilmiş ağı görmediği örneklerden her bir fonksiyon türünü ifade eden Y değerleri verilmiştir. Program bu girdiler için 4 ayrı fonksiyon türünün $R, R^2, AdjR^2, Se$ değerlerini hesaplamıştır. Bu değerleri karşılaştırarak en büyük R ve en küçük Se değerine sahip olanı seçerek uygun fonksiyon tipini belirlemiştir. Aynı Y değerleri bu kez YSA programının sorgu kısmında kullanılmıştır. YSA programının cevap verdiği eğri türlerinin doğru ve SPSS programı ile aynı olduğu görülmüştür. SPSS programıyla karşılaştırıldığında YSA'nın 4 fonksiyon için 0001,0010,1000,0100 çıktıları vererek tahmin yapabildiği ispatlanmıştır.

V. SONUÇ

Bu çalışmada ele alınan dört zaman serisi fonksiyonlarını belirlemenin ötesinde yapay sinir ağları ile verilerin ifade ettikleri fonksiyonu tespit etmenin olabirliğini göstermektedir. Verilerin gösterdiği fonksiyon ya da ilişki ile ilgili mevcut teorik fonksiyonları tek tek mukayese etmek zaman alıcı ve karmaşık bir prostedir. Bu dezavantajları gidermek için klasik programlamaya alternatif olarak daha yüksek performans ile YSA yaklaşımı gerçekleştirilmiştir.

V.1 Çalışmanın Katkısı

1.YSA ile fonksiyon türü tespitinin olurluğu gösterilmiştir. Farklı fonksiyon tiplerini ve farklı YSA modellerini göz önüne alınacak eklemeler yapmak çok zor değildir. Dolayısıyla, ufak değişiklik yaparak daha kapsamlı ve uygulanabilir bir sonuca ulaşılabilir.

2.Yapay sinir ağı, bir tarama yöntemi gibi kullanılarak farklı bir işlev üstlenmesi sağlanmıştır. Başlangıç ağırlıkları ve ağı parametreleri ile yapay sinir ağı belirli epoklar(örnek setinin ağı bir kez gösterilmesi) arasında eğitilip ağırlıkları saklanarak bir tek ağıdan biden fazla ağı elde edilerek çözüm uzayında birden fazla çözümler üretilmekte ve iyi çözümler budanmaktadır. Tarama yöntemi gibi kullanılarak yapay sinir ağının çözüm uzayında iyi çözümleri yakalayabileceği gösterilmektedir. Dolayısıyla YSA ile yeni bir yaklaşım gerçekleştirilmiştir.

V.2 Çalışmanın Araladığı Yeni Araştırma Konuları

Mevcut tüm fonksiyonlar için yapılacak bir fonksiyon tanıma sistemi ve bu çalışmanın bir ileri adımı olacaktır. Hatayı geriye yayma ağı yerine başka ağlar kullanılabilir. Örneğin LVQ ağı, daha iyi ve hızlı öğrenme performansı ve mevcut olmayan fonksiyonların da tespiti açısından kullanılabilir. Hatta, mevcut modele LVQ ağı da eklenerek çözüm uzayında daha da farklı çözümlere erişmek gerçekleştirilebilir.

KAYNAKLAR

- [1]. Uysal, M., Roubi, M.S., "Artificial Neural Network versus Multiple Regression in Tourism Demand Analysis" Journal of Travel Research, Nov99, Vol.38
- [2]. ÖZALP, A., ANAGÜN, A.S., "Sektörel Hisse Senedi Fiyat Tahmininde Yapay Sinir Ağı Yaklaşımı ve Klasik Tahminleme Yöntemleri ile Karşılaştırılması" Endüstri Mühendisliği Dergisi Cilt:12 Sayı:3-4 Sayfa: (2-17)
- [3]. Aiken, M., "Using a Neural Network to Forecast Inflation" Industrial Management & Data Systems 99/7 [1999] 296-301
- [4]. Kumar, L.R., "Estimation of Simultaneous Econometric Equations Using Neural Networks" IEEE 1999.
- [5]. HILL, T., O'CONNOR, M., REMUS, W., "Neural Network Models for Time Series Forecasts" Management Science, Vol.42, No.7, July 1996
- [6]. REFENES, A.N., ZAPRANIS, A., FRANCIS, G., "Stok Performance Modeling Using Neural Networks: A Comparative Study With Regression Models" Neural Networks, Vol. 7, No.2, pp.375-388, 1994.
- [7]. GÜLSEÇEN, S., "Yapay Sinir Ağları, İşletme Alanında Uygulanması ve Bir Örnek Çalışma", Doktora Tezi İ.Ü. İşletme Fak., İstanbul, 1993.
- [8]. CHAKRABORTY, K., MEHROTRA, K., MOHAN, C.K. and RANKA, S., "Forecasting the behavior of Multivariate Time Series Using Neural Networks" Neural Networks, Vol.5, pp.961-970, 1992.
- [9]. Yoon, Y., Swales, G., "Predicting Stock Price Performance: A Neural Network Approach" Southwest Missouri State University Springfield, Missouri 65804-0095
- [10]. ÖZTEMEL, E., AYDIN, M.E., "Yapay Sinir Ağları ile Taguchi Metodunun Karşılaştırılması"
- [11]. COTTREL, M., GIRARD, B., GIRARD, Y., MANGEAS, M., MULLER, C., "Neural Modeling for Time Series: A Statistical Stepwise Method for Weight Elimination" IEEE Transactions on Neural Networks, Vol.6, No.6, November 1995.
- [12]. HORN, D., GINZBERG, I., "Learning The Rule of a Time Series" International Journal of Neural Systems, Vol.3, No.2 (1992) 167-177.

- [13]. CHU,C-H.,: "Neural Network System for Forecasting Method Selection" Decision Support Systems, 12(1994) 13-24.
- [14]. LEE,K.C.,PARK,S.J.: "Decision Support in Time Series Modeling by Pattern Recognition" Decision Support Systems 4(1998) 199-207.
- [15]. ÖZTEMELE,E.,AYDIN,M.E.,: "Neural Network Based Experimental Design Method and an Industrial Application" Tr.J.of Engineering and Environmental Sciences 20 (1996) 73-78.